arXiv:2603.02178v1 [cs.LG] 2 Mar 2026

Top-n 白化下用于在线独立成分分析的储层子空间注入

Wenjun Xiao、Yuda Bi、Vince Calhoun，*IEEE*会士

摘要—**储层扩展可提升非线性混合条件下的在线独立成分分析（ICA）性能，但 top-n白化可能会丢弃注入特征。我们将这一瓶颈形式化为储层子空间注入（RSI）：只有当注入特征进入保留特征子空间且不挤占直通方向时，才会发挥作用。RSI诊断（IER、SSO、 ρ_x）揭示了我们 top-n设置中的一种失效模式：增强注入会提高 IER，却挤占直通能量（ρ_x： $1.00\to0.77$），使 SI-SDR 最多降低2.2分贝。带保护的 RSI 控制器可维持直通保留率，并将平均性能恢复至距基线0.1分贝以内，且具备 $1/N$ 缩放能力。在保留直通方向的情况下，RE-OICA 在非线性混合条件下比原始在线独立成分分析高出 $+1.7$ 分贝，并在所测试的超高斯基准测试中取得正的 SI-SDR（$+0.6$ 分贝）。**

索引词—**盲源分离、独立成分分析、储备池计算、回声状态网络、在线学习、自然梯度**

一、引言

独立成分分析（ICA）从其线性混合中恢复潜在的独立源；在标准线性瞬时混合模型下，只要至多有一个源为高斯分布，该问题即可辨识 [1], [2]。经典批处理算法——Infomax [3], FastICA [4], JADE [5]——已广泛应用于神经影像学 [6], [7],、电信和音频处理；综述与教材论述见 [8], [9] [2]。然而，批处理独立成分分析需要完整数据以及固定的混合矩阵，从而推动了逐样本在线独立成分分析。Amari 的自然梯度 [10], [11]提供了一种对混合矩阵条件数敏感性更低的等变更新，而在线递归独立成分分析（ORICA）将递归最小二乘白化与自然梯度更新相结合，用于实时脑电信号源分离 [12]。我们的原始在线独立成分分析受 ORICA 启发，并非完整复现：它保留 ORICA 的自然梯度解混更新 [12]，但以指数移动平均协方差和周期性特征分解（每 64 步一次）取代 RLS 白化。它是不含储备池的 RE-OICA 消融实验，旨在单独考察 RSI 的效应，而不是提供与 ORICA 的直接基准测试。随机逼近方法进一步将在线独立成分分析扩展至张量型或多变量分量设置 [13], [14], [15]。尽管如此，这些方法都在观测空间中运行：在非线性混合或非线性源失真 [16], [17], 下，纯粹的线性 解混在**x** 中可能并不充分。非线性独立成分分析通常需要辅助变量或时间结构才能保证可辨识性 [18], [19], [20], ，而深度学习解决方案往往牺牲在线、低延迟处理。

储备池计算 [21], [22] 为观测空间解混提供了一种替代方案：回声状态网络（ESN）将输入映射为固定的高维非线性特征，从而近似衰减记忆泛函 [23]。近期研究将 ESN 与非线性动力学的核方法和随机特征视角联系起来 [24], [25]。基于储备池的分离已被用于结合训练后的读出层进行离线去噪 [26]；相比之下，储备池扩展在线独立成分分析（RE-OICA）面向完全在线、逐样本的盲源分离（BSS），且无需训练储备池或读出层。一个实际问题是，低延迟在线流程通常采用前-n白化，这可能丢弃注入的储备池特征；如果没有保留诊断，就难以判断何时扩展是有益的。

这一空白促使我们开展本项工作。我们将储备池扩展在线独立成分分析重新表述为一个子空间注入 问题，并作出以下贡献：

(i) RSI诊断（IER、SSO、 ρ_x），用于量化前-n 白化下的注入特征保留率和直通保留情况。(ii) 一种挤出机制——通过受控实验（10个随机种子、尺度不变信号失真比（SI-SDR）$_{\text{SC}}$）加以验证——表明更强的注入可以提高 IER，却会降低 ρ_x 并使 SI-SDR 恶化；在非线性混合下，只有保留直通时才会带来改进。(iii) 一种防挤出控制器，通过调节 α_t 来维持较高的 ρ_x，同时允许有益的注入，并且除白化特征分解外几乎不增加额外开销。

II. 模型与主要结果

A. 设定与符号

我们观测到$\mathbf{x}_t\in\mathbb{R}^n$ 由n 个独立源$\mathbf{s}_t\in\mathbb{R}^n$ 生成，其中 $\mathbb{E}[\mathbf{s}_t]=\mathbf{0}$, $\mathbb{E}[\mathbf{s}_t\mathbf{s}_t^\top]=\mathbf{I}_n$，且具有有限四阶矩。我们考虑：

$$\text{(Static)}\ \mathbf{x}_t=\mathbf{A}\,\mathbf{s}_t, \tag{1}$$

$$\text{(Time-varying)}\ \mathbf{x}_t=\mathbf{A}(t)\,\mathbf{s}_t,\quad \mathbf{A}(t)=\mathbf{A}_0+\varepsilon\sin\!\left(\tfrac{2\pi ft}{T}\right)\Delta, \tag{2}$$

$$\text{(Nonlinear)}\ \mathbf{x}_t=g(\mathbf{A}\,\mathbf{s}_t)+\eta_t, \tag{3}$$

W. Xiao 任职于美国华盛顿特区乔治·华盛顿大学计算机科学系。Y. Bi 任职于神经影像与数据科学转化研究三校联合中心（TReNDS）、佐治亚州立大学、佐治亚理工学院和埃默里大学，地址为美国佐治亚州亚特兰大 30303（电子邮件：ybi@gsu.edu）。V. D. Calhoun 任职于神经影像与数据科学转化研究三校联合中心（TReNDS）、佐治亚州立大学、佐治亚理工学院和埃默里大学，地址为美国佐治亚州亚特兰大 30303；同时任职于佐治亚理工学院电气与计算机工程学院，地址为美国佐治亚州亚特兰大 30332（电子邮件：vcal-houn@gsu.edu）。

其中$\mathbf{A},\mathbf{A}0,\Delta\in\mathbb{R}^{n\times n}$，$g$是逐分量 Lipschitz 连续的（例如双曲正切），η_t 是独立同分布的高斯变量，f 是调制频率，且T 是用于归一化的序列时域长度。

RE-OICA使用固定的储备池和投影，将直通特征与注入特征拼接，然后应用top-n白化和自然梯度独立成分分析：

$$\begin{aligned}&\mathbf{r}_t=\mathrm{ESN}(\mathbf{x}_{1:t})\in\mathbb{R}^N,\\&\mathbf{p}_t=c_N\mathbf{W}_{\mathrm{read}}\mathbf{r}_t\in\mathbb{R}^d,\qquad \mathbf{u}_t=[\mathbf{x}_t;\,\alpha_t\mathbf{p}_t]\in\mathbb{R}^{n+d},\\&\mathbf{z}_t=\mathrm{Whiten}_n(\mathbf{u}_t)\in\mathbb{R}^n,\qquad \mathbf{y}_t=\mathrm{ICA}(\mathbf{z}_t)\in\mathbb{R}^n,\end{aligned}\tag{4}$$

其中 α_t 是由RSI控制的注入尺度（定义见下文）。除非另有说明，n=3，N=500，d=20。我们始终使用$k=n$ 的top-k白化。

B. 储备池编码

我们使用具有固定随机权重的稀疏回声状态网络（回声状态网络）储备池 [21],[27], [28] 。令$\mathbf{W}_{\mathrm{in}}\in\mathbb{R}^{N\times n}$，$\mathbf{W}_{\mathrm{res}}\in\mathbb{R}^{N\times N}$（稀疏，谱半径 ρ），以及$\mathbf{b}\in\mathbb{R}^N$。状态更新为

$$\mathbf{r}_t=(1-\alpha_r)\mathbf{r}_{t-1}+\alpha_r\,\sigma(\mathbf{W}_{\mathrm{in}}\mathbf{x}_t+\mathbf{W}_{\mathrm{res}}\mathbf{r}_{t-1}+\mathbf{b}),\tag{5}$$

泄漏率为 $\alpha_r\in(0,1]$，且 $\sigma=$ 双曲正切逐元素应用。

命题 1（回声状态性质）。设 σ 是 $L\sigma$-*Lipschitz* 连续的。若 $\rho_{\mathrm{eff}}:=(1-\alpha_r)+\alpha_r L_\sigma\|\mathbf{W}_{\mathrm{res}}\|<1$，则对于由相同输入驱动的任意两个初始状态 $\mathbf{r}_0,\mathbf{r}'_0$，$\|\mathbf{r}_t-\mathbf{r}'_t\|\le\rho_{\mathrm{eff}}^{\,t}\|\mathbf{r}_0-\mathbf{r}'_0\|$。

证明。令 $a_t=\mathbf{W}_{\mathrm{in}}\mathbf{x}_t+\mathbf{b}$。根据 Lipschitz 连续性，

$$\begin{aligned}\|\mathbf{r}_t-\mathbf{r}'_t\|&\le(1-\alpha_r)\|\mathbf{r}_{t-1}-\mathbf{r}'_{t-1}\|+\alpha_r L_\sigma\|\mathbf{W}_{\mathrm{res}}\|\,\|\mathbf{r}_{t-1}-\mathbf{r}'_{t-1}\|\\&=\rho_{\mathrm{eff}}\|\mathbf{r}_{t-1}-\mathbf{r}'_{t-1}\|.\end{aligned}$$

迭代即可得到结论。 □

利用 $\|\mathbf{W}_{\mathrm{res}}\|$ 中的诱导算子范数，可得到一个充分的（可能较保守的）压缩条件。因此，对初始状态的依赖会呈指数衰减（渐消记忆）。

读出投影与直通。固定随机$\mathbf{W}_{\mathrm{read}}\in\mathbb{R}^{d\times N}$后，定义 $\mathbf{p}_t=c_N\mathbf{W}_{\mathrm{read}}\mathbf{r}_t\in\mathbb{R}^d$ 和 $\mathbf{u}_t=[\mathbf{x}_t;\ \alpha_t\mathbf{p}_t]\in\mathbb{R}^{n+d}$。这将白化成本从 $O(N^3)$ 降至 $O((n+d)^3)$，同时保留原始输入下限。我们测试$c_N\in\{1/N,1/\sqrt{N}\}$；有效注入幅度为 $\alpha_t c_N$，其中c_N 在每个分支中固定，而 α_t 仅在白化刷新时调整。

C. 动机：随机特征近似

随机特征展开 [29], [30] 为非线性解混中的储层提升提供了动机，但此处的操作瓶颈在于 top-n 白化后的保留。

命题2（动机线性化界）。在针对$\psi=\mathbf{A}^{-1}\circ g^{-1}$的标准随机特征积分表示假设下，来自 N 个无记忆随机特征的总体最优线性读出满足以下关系，其中 $\Phi:\ \mathbb{R}^n\to\mathbb{R}^N$ 为随机特征映射，且 B 对积分表示系数范数给出了界：

$$\mathbb{E}_{\mathbf{W}_{\mathrm{in}},\mathbf{b}}\Big[\min_{\mathbf{M}}\mathbb{E}_{\mathbf{x}}\big[\|\mathbf{M}\Phi(\mathbf{x})-\mathbf{s}\|^2\big]\Big]\ \le\ \frac{nB^2}{N}.\tag{6}$$

备注。命题2是关于无记忆特征的原理性总体结果。我们的核心贡献是在在线循环流水线中对 top-n 保留进行诊断与控制。

D. 储层子空间注入（*RSI*）

我们构造白化输入

$$\mathbf{u}_t=[\mathbf{x}_t;\alpha_t\mathbf{p}_t],\qquad \mathbf{p}_t=c_N\mathbf{W}_{\mathrm{read}}\mathbf{r}_t,\tag{7}$$

并令 $\mathbf{V}_n\in\mathbb{R}^{(n+d)\times n}$ 为每次白化刷新时 $\mathbf{C}_t(\alpha_t)$ 的 top-n 特征向量。定义未缩放拼接$\tilde{\mathbf{u}}_t=[\mathbf{x}_t;\ \mathbf{p}_t]$ 其分块协方差为

$$\tilde{\mathbf{C}}_t=\mathrm{Cov}(\tilde{\mathbf{u}}_t)=\begin{bmatrix}\mathbf{C}_{xx}&\mathbf{C}_{xp}\\\mathbf{C}_{px}&\mathbf{C}_{pp}\end{bmatrix}.$$

在注入下，$\mathbf{u}_t=[\mathbf{x}_t;\ \alpha_t\mathbf{p}_t]$ 的协方差为

$$\mathbf{C}_t(\alpha_t)=\begin{bmatrix}\mathbf{C}_{xx}&\alpha_t\mathbf{C}_{xp}\\\alpha_t\mathbf{C}_{px}&\alpha_t^2\mathbf{C}_{pp}\end{bmatrix}.$$

令$\mathbf{P}_x=\mathrm{diag}(\mathbf{I}_n,\mathbf{0}_{d\times d})$ 和$\mathbf{P}_p=\mathrm{diag}(\mathbf{0}_{n\times n},\mathbf{I}_d)$ 为坐标投影算子。只有当储备池特征保留在n 大特征子空间$\mathbf{C}_t(\alpha_t)$ 中时，它们才有帮助，具体量化为

$$E_p=\mathrm{tr}\Big(\mathbf{V}_n^\top\mathbf{P}_p\mathbf{C}_t(\alpha_t)\mathbf{P}_p\mathbf{V}_n\Big),\tag{8}$$

$$E_x=\mathrm{tr}\Big(\mathbf{V}_n^\top\mathbf{P}_x\mathbf{C}_t(\alpha_t)\mathbf{P}_x\mathbf{V}_n\Big),\tag{9}$$

$$\mathrm{IER}_t=\frac{E_p}{E_x+E_p},\qquad \mathrm{SSO}_t=\frac{\|\mathbf{P}_p\mathbf{V}_n\|_F^2}{\|\mathbf{V}_n\|_F^2}.\tag{10}$$

IER 表示来自储层坐标的保留能量份额，而 SSO 表示储层坐标上的保留子空间重叠比例（不受尺度影响）。由于$\mathbf{V}_n^\top\mathbf{V}_n=\mathbf{I}_n$，我们有 $\|\mathbf{V}_n\|_F^2=n$ 且 $\mathrm{SSO}_t\in[0,1]$。我们还跟踪保留直通比$\rho_{x,\,t}=E_x/\mathrm{tr}(\mathbf{C}_{xx})$，即经前$n$ 项选择后保留的直通方差。

防挤出控制器。我们将注入控制表述为 $\max_\alpha \mathrm{IER}(\alpha)$，约束条件为 $\rho_x(\alpha)\ge\rho_x^\star$，并采用一条跟踪规则：当 $\mathrm{IER}_t<\mathrm{IER}^\star$ 时，α_t 会上升；当 $\rho_{x,\,t}<\rho_x^\star$ 时则会受到惩罚：

$$\delta_t=\kappa(\mathrm{IER}^\star-\mathrm{IER}_t)-\kappa_g[\rho_x^\star-\rho_{x,t}]_+/\rho_x^\star,\tag{11}$$

$$\alpha_{t+1}=\mathrm{clip}\big(\alpha_t e^{\delta_t},\alpha_{\min},\alpha_{\max}\big),\tag{12}$$

其中，$[\cdot]_+=\max(\cdot,\ 0)$，$\kappa>0$ 为 IER跟踪增益，$\kappa_g>0$为防护增益，$[\alpha_{\min},\alpha_{\max}]$ 为截断边界。我们保守地设置 $\rho_x^\star$（例如 0.95），以保留 ≥95% 的直通方差；只要运行时避开挤出区间（$\rho_x<0.9$；表II），性能对具体取值并不敏感。同样，$\mathrm{IER}^\star$ 被设为实际运行目标，以便在所述协议下稳定地在线运行。该更新使用已计算出的协方差与特征空间统计量。

命题3（储备池进入条件（块对角情形））。设 $\tilde{\mathbf{C}}_t$ 按块划分为 $\begin{bmatrix}\mathbf{C}_{xx}&\mathbf{C}_{xp}\\\mathbf{C}_{px}&\mathbf{C}_{pp}\end{bmatrix}$，满足 $\tilde{\mathbf{u}}_t=[\mathbf{x}_t;\ \mathbf{p}_t]$，并假设 $\mathbf{C}_{xp}=\mathbf{0}$。若

$$\lambda_{\max}(\alpha_t^2\mathbf{C}_{pp})>\lambda_n(\mathbf{C}_{xx}),\tag{13}$$

其中 $\lambda_n(\mathbf{C}_{xx})$ 表示 $\mathbf{C}_{xx}$ 的第 n 大特征值，则至少有一个前 n 个特征向量具有非零储备池分量，因此 $\mathrm{SSO}_t>0$。

概述。在$\mathbf{C}_{xp}=\mathbf{0}$ 中，$\tilde{\mathbf{C}}_t$，$\mathbf{C}_t(\alpha_t)=\mathrm{diag}(\mathbf{C}_{xx},\alpha_t^2\mathbf{C}_{pp})$，因此其谱是两个块的谱的并集。

给定的严格不等式意味着至少有一个储备块特征值进入前 n 个集合，因此保留特征空间与储备池有非零重叠。 □

观察（块对角情形下的挤出效应）。在$\mathbf{C}_{xp} = \mathbf{0}$ 中，如果 $\tilde{\mathbf{C}}_t$，且 $\lambda_{\max}(\alpha_t^2 \mathbf{C}_{pp}) > \lambda_n(\mathbf{C}_{xx})$，则至少有一个储备主导方向进入前$n$ 特征子空间，并取代一个直通方向，这意味着$\rho_{x,t}$降低。对于$\mathbf{C}_{xp} \neq \mathbf{0}$ 中的 $\tilde{\mathbf{C}}_t$，$\mathbf{C}_t(\alpha_t)$中的耦合会扰动这一排序。当 $\lambda_n(\mathbf{C}_{xx})$附近存在不可忽略的特征值间隙，且$\|\mathbf{C}_{xp}\|$适中时，Davis–Kahan 型界意味着其将从块对角极限连续变化；当储备池诱导的方差在前n谱中变得具有竞争力时，仍可能出现挤出效应。

注。块对角极限使这一机制更加清晰：前n选择是直通块谱与储备池块谱之间的竞争。在实验中，归一化的跨块相干性在不同注入强度下近似保持不变，因此性能变化主要由相对块能量驱动，而不是由耦合的大幅变化所致。

解读。 在块对角极限下，SSO>0 （命题 3）是储备影响的必要条件，但并非提升分离度的充分条件：当储备池特征值将直通特征值挤出前n 个基向量时， ρ_x 会下降，SI-SDR 也会恶化（挤出效应；量化结果见表II）。受保护控制器（11）通过调整 α_t 来缓解这一问题，以便在实践中使$\rho_{x,\,t}$ 保持在 $\rho_x^\star$ 附近。

E. 在线白化与自然梯度独立成分分析

在线白化。 对于$\mathbf{u}_t = [\mathbf{x}_t;\ \alpha_t \mathbf{p}_t] \in \mathbb{R}^{n+d}$，我们使用遗忘因子 $\lambda \in (0,\ 1)$更新均值和协方差：

$$\mu_t = \lambda\, \mu_{t-1} + (1-\lambda)\, \mathbf{u}_t, \tag{14}$$

$$\mathbf{C}_t = \lambda\, \mathbf{C}_{t-1} + (1-\lambda)\, (\mathbf{u}_t - \mu_t)(\mathbf{u}_t - \mu_t)^\top. \tag{15}$$

在特征值分解之前，我们应用对角加载$\mathbf{C}_t \leftarrow \mathbf{C}_t + \varepsilon \mathbf{I}$ （$\varepsilon = 10^{-6}$）。每隔 Δ_w 步，我们计算前n 个特征子空间$\mathbf{V}_n$ 和特征值$\mathbf{D}_n$，构造 $\mathbf{W}_{\text{wh}} = \mathbf{D}_n^{-1/2} \mathbf{V}_n^\top$，并对白化后的$\mathbf{z}_t = \mathbf{W}_{\text{wh}}$（$\mathbf{u}_t - \mu_t$） $\in \mathbb{R}^n$。每次刷新时，我们使用当前前n 个特征子空间评估 IER/SSO 和$\rho_{x,\,t}$，并通过（11）更新 α_{t+1}；两次刷新之间保持 α_t 不变。保留前n 个特征向量与源数量相匹配，并去除低方差方向；RSI 控制储备方向是否保留在该保留子空间中。

自然梯度独立成分分析。 在$\mathbf{z}_t$上，我们通过自然梯度 [10]更新解混矩阵 $\mathbf{W}_t \in \mathbb{R}^{n \times n}$：

$$\mathbf{W}_{t+1} = \mathbf{W}_t + \eta \left(\mathbf{I}_n - \phi(\mathbf{y}_t)\mathbf{y}_t^\top\right)\mathbf{W}_t, \qquad \mathbf{y}_t = \mathbf{W}_t \mathbf{z}_t, \tag{16}$$

其中 ϕ =双曲正切和 $\eta > 0$。每经过 Δ_o 步，我们应用 $\mathbf{W} \leftarrow (\mathbf{W}\mathbf{W}^\top)^{-1/2}\mathbf{W}$ 以防止漂移。

算法 1（RSI 控制的 RE-OICA）。每个样本：更新 $\mathbf{r}_t$，$\mathbf{p}_t$；构造 $\mathbf{u}_t = [\mathbf{x}_t;\ \alpha_t \mathbf{p}_t]$；刷新时重新计算 top-$n$白化，评估 IER/SSO/$\rho_{x,\,t}$，并通过 (11) 更新 α_{t+1}；白化得到$\mathbf{z}_t$；应用 (16)。

表 I 最后 5,000 个样本（10 个随机种子，均值±均值标准误）：尺度不变信号失真比$_{\text{sc}}$ （分贝），均值 $|r|$，计数（RE-OICA ＞原始版本）。

机制	方法	尺度不变信号失真比$_{\text{sc}}$	Corr	计数
静态	RE-OICA	-5.9 ± 1.0	0.44 ± 0.04	6/10
	原始版本	-6.8 ± 1.0	0.41 ± 0.04	
时变	RE-OICA	-6.0 ± 1.1	0.44 ± 0.04	7/10
	原始版本	-6.1 ± 1.1	0.44 ± 0.04	
非线性	RE-OICA	$\mathbf{-7.0 \pm 1.1}$	$\mathbf{0.41 \pm 0.04}$	7/10
	原始版本	-8.7 ± 1.0	0.35 ± 0.03	

FastICA（批处理）：静态 35.4/1.00、时变 23.1/1.00、非线性 2.4/0.78（SI-SDR$_{\text{sc}}$/相关性）。

III. 实验

源信号与混合。我们使用 n=3 个标准化源信号：洛伦兹（x 分量）、Mackey–Glass（τ=17）以及线性啁啾信号（10 秒内从 0.5 到 5Hz）。混合遵循 (1)–(3)：静态（$\mathbf{A}$ 固定）、时变（ε=0.3，f=0.5 Hz）和非线性（g=双曲正切($\gamma\cdot$)，γ=0.8，信噪比= 10 分贝，并叠加白色高斯噪声（AWGN））。混合矩阵为随机矩阵，条件数为 ≤ 5。

方法。 我们比较 RE-OICA-base（回声状态网络储层：N =500，稀疏度 5%， ρ=0.95, α_r=0.1, c_{in}=0.1 输入缩放，固定随机$\mathbf{W}_{\text{read}} \in \mathbb{R}^{d \times N}$，具有$d$=20，基线$c_N = 1/N$）、RE-OICA-sqrt（$c_N = 1/\sqrt{N}$）、RE-OICA-RSI（对 (11) 采用有保护的方式，并使用 IER*=0.25, $\rho_x^\star$=0.95, κ=0.3, κ_g=3, $\alpha_t \in [0.1, 10]$）、无保护的 RSI反事实基线（IER*=0.25，无 ρ_x 保护），以及原始在线独立成分分析和 FastICA 基线。所有在线方法使用相同的后端：指数移动平均白化（λ=0.995, Δ_w=64）和自然梯度独立成分分析（$\eta = 5 \times 10^{-3}$, Δ_o=50）。原始在线独立成分分析（受 ORICA 启发）将该后端直接应用于$\mathbf{x}_t$，不进行储层扩展（采用与 ORICA 相同的自然梯度更新 [12]，但使用指数移动平均白化加周期性特征分解，而非 ORICA 的 RLS 白化）。*FastICA* [4] 为离线参考（完整批处理、双曲余弦对数非线性函数；参见 [2], [31]）。在线运行使用 1000 个样本进行白化预热（冻结 ICA），并采用 2000 个样本的学习率渐增；图 1(a)报告 10 个随机种子的运行中未移位 SI-SDR 均值±均值标准误（SEM）。

指标与对齐。在最后 5,000 个样本上，我们计算时滞感知相关性 $\rho_{ij} = \max_{|\tau| \leq 200} |\text{corr}(s_i, y^{(\tau)}_j)|$，并对 $[\rho_{ij}]$ 使用匈牙利匹配以获得排列π；在重叠区间上，按使相关性最大的时滞评估匹配后的输出。我们报告尺度不变信号失真比$_{\text{sc}}$ [32]、 [33]、均值 $|r|$ 以及 RSI诊断（IER/SSO 和 ρ_x）。运行曲线显示向后 2,000 个样本的未移位SI-SDR，而稳态 SI-SDR$_{\text{sc}}$ 则经过时滞补偿。结果为 10 个随机种子的均值±均值标准误；计数仅作描述性统计。

结果（图 1，表 I）。 (*a*) 收敛。在时变混合条件下，图 1(a) 展示了 10 个随机种子的运行中的未移位 SI-SDR 均值±均值标准误；两种方法均在 ∼3,000 个样本后趋于稳定。

(b) 跨状态比较（表 *I*）。在这一协议下，RE-OICA 在三种机制中均优于原始版本，其中非线性混合下的提升最大（+1.7分贝；表 I）。FastICA 在此基准测试中作为离线参考；在这些混沌/振荡压力测试信号源上，在线尺度不变信号失真比$_{\text{sc}}$ 为负，而批处理 FastICA 也仅达到 +2.4分贝

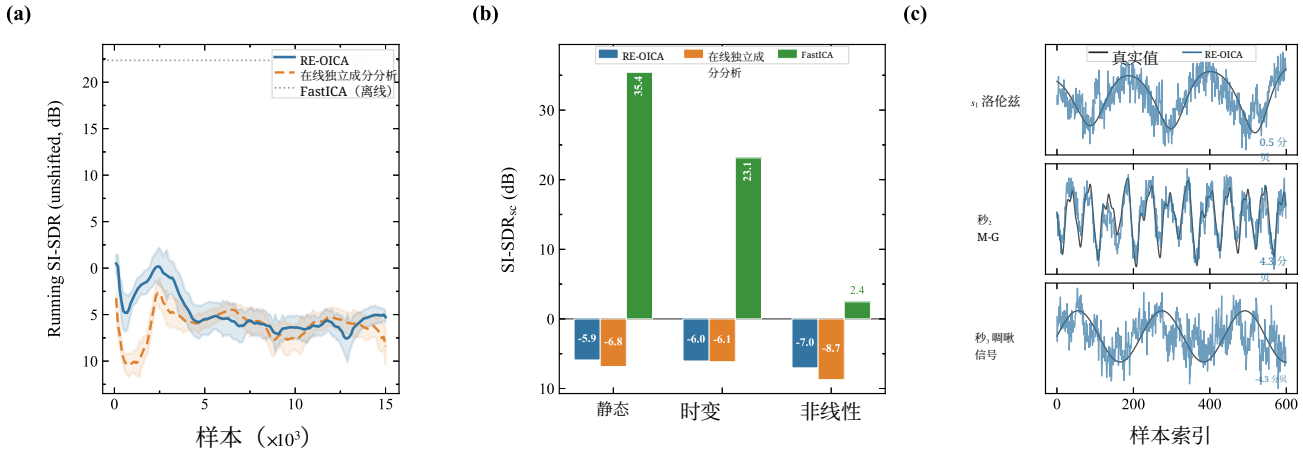

图 1. RE-OICA验证（T=15，000，n=3，10 个随机种子）。(a) 运行中的未移位 SI-SDR（最后 2 000 个）：RE-OICA、原始版本、FastICA。(b) 各机制下的稳态 SI-SDRsc（时滞补偿）。(c) 非线性叠加（最后 600 个）：真实值与 RE-OICA；角标显示各源未移位尺度不变信号失真比。

在非线性混合下。胜出次数仅作描述性统计，不具有推断意义。

标准盲源分离验证。对于标准超高斯源（拉普拉斯分布、方波、锯齿波；T=30，000；采用相同的混合矩阵协议，条件数为 ≤5 ，且白化/独立成分分析超参数相同），RE-OICA-base（$1/N$缩放）达到 +0.6±1.2分贝，而原始版本为 −2.9±2.3 分贝（Δ=+3.5分贝，10 个随机种子中有 7 个）。在轻度非线性条件下（g=双曲正切(0.5·)，信噪比= 20 分贝），RE-OICA-base 达到−1.5±1.0分贝，而原始版本为 −3.6±1.4 分贝（Δ=+2.1 分贝，10 个随机种子中有 9 个）。因此，混沌源数值为负与该协议下的任务难度相符。

(c) 波形质量。 叠加图（非线性，最近 600 个样本）显示，RE-OICA 在定性上能够跟踪洛伦兹动力学和啁啾动力学；Mackey–Glass 仍然是最难处理的信号源（图 1(c)）。

计算成本。 每个样本的计算成本主要来自储层编码（稀疏$\mathbf{W}_{\text{res}}$ 乘法，$O(\text{nnz})$，其中 nnz =nnz($\mathbf{W}_{\text{res}}$)）；摊销后的$O((d+n)^3/\Delta_w)$特征值分解和$O(n^2)$独立成分分析更新，在我们的实现设置中，对于$d+n$=23、n=3 而言，计算负担较小。

消融研究（图2，表II）。所有消融实验均遵循相同的协议（10 个随机种子）并使用 SI-SDRsc 进行评估。

(a) N 扫描与 RSI 机制（图 *2(a)*，*表II*）。在基线 $1/N$ 缩放下，SI-SDRsc 随N变化几乎保持平稳，且 IER $\rho_x \approx 1$ 非常低。无约束的 $1/\sqrt{N}$ 缩放会提高 IER，但因挤出效应而降低 SI-SDRsc ；而有保护的 RSI 分支则恢复至接近基线性能（表II）。

(b) 架构（图*2(b)*）。循环回声状态网络与无记忆随机特征（随机特征）表现相近，在时变混合下略高于原始版本（Δ=+0.1–0.2分贝），这表明在该基准测试中，增益的主要贡献者更可能是高维非线性扩展，而非渐消记忆。

(c) 漂移强度（图*2(c)*）。在 $\varepsilon \in \{0.1, 0.3, 0.8\}$范围内，RE-OICA与原始版本相当或略高（Δ=+0.1–0.8分贝），且对 ε不存在单调依赖。

关于读出维度、直通

表II 非线性（10个随机种子）：尺度不变信号失真比sc （分贝，均值±均值标准误），IER/ρ_x 稳态

，计数与 RE-OICA-base 对比。

分支	尺度不变信号失真比sc	IER	ρ_x	计数 (参考)
RE-OICA-base ($1/N$)	−7.0±1.1	<0.001	1.00	
RE-OICA-sqrt ($1/\sqrt{N}$)	−8.7±1.0	0.016	0.94	2/10
无保护RSI（反事实，IER*=0.25）	−9.2±1.0	0.255	0.77	2/10
RE-OICA-RSI（有保护，$\rho_x^\star$=0.95）	−7.1±1.1	0.007	0.98	5/10

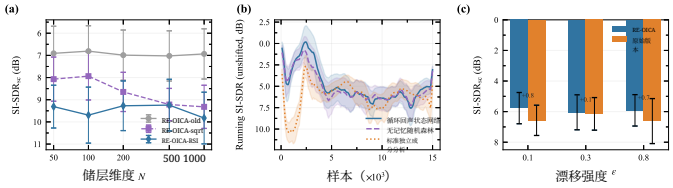

图2. 消融研究（10个随机种子，均值±均值标准误）。**(a)** N扫描：非线性混合下的三个缩放分支。**(b)** 架构：回声状态网络、随机特征与原始版本（时变）。**(c)** 漂移扫描：$\varepsilon \in \{0.1, 0.3, 0.8\}$。

移除和非线性类型的其他消融实验呈现出定性上相似的趋势（受篇幅限制，未展示结果）。

机制概要（表II）。RSI诊断揭示了一种挤出权衡：提高IER会降低直通保留率 ρ_x 并降低尺度不变信号失真比sc，而有保护的控制器保留 ρ_x 并恢复至接近基线性能。块间相干性保持稳定（0.38–0.45），表明储层块能量增加 $\|\mathbf{C}_{pp}\|$ ，而非耦合变化。

IV. 结论

Top-n 白化使储备池扩展成为一个秩预算问题：保留特征空间之外的特征无法发挥作用。RSI诊断（IER、SSO、 ρ_x）可以预测结果；增强注入虽能提高 IER，却可能降低 ρ_x 和 SI-SDR（表II）。在我们的协议下，低开销的受保护控制器能够维持 $\rho_x \approx \rho_x^\star$，并将平均性能恢复到距基线 $1/N$缩放 0.1 分贝以内。未来工作应增加有用的块间结构，而不应只增加 $\|\mathbf{C}_{pp}\|$。

参考文献

[1] P. Comon，“独立成分分析：一个新概念？”《信号处理》，第 36 卷，第 3 期，第 287–314 页，1994 年。[2] A. Hyv¨arinen、J. Karhunen 和 E. Oja，《独立成分分析》。Wiley，2001 年。[3] A. J. Bell 和 T. J. Sejnowski，“盲分离与盲解卷积的信息最大化方法”，《神经计算》，第 7 卷，第 6 期，第 1129–1159 页，1995 年。[4] A. Hyv¨arinen，“独立成分分析的快速稳健不动点算法”，《IEEE神经网络汇刊》，第 10 卷，第 3 期，第 626–634 页，1999 年。[5] J.-F. Cardoso 和 A. Souloumiac，“非高斯信号的盲波束形成”，《IEE Proceedings F（雷达与信号处理）》，第 140 卷，第 6 期，第 362–370 页，1993 年。[6] V. D. Calhoun、T. Adali、G. D. Pearlson 和 J. J. Pekar，“利用独立成分分析从功能磁共振成像数据中进行群体推断的方法”，《人脑图谱》，第 14 卷，第 3 期，第 140–151 页，2001 年。[7] V. D. Calhoun 和 T. Adali，“功能磁共振成像的多受试者独立成分分析：十年来对内在网络、默认模式和神经诊断发现的研究”，《IEEE生物医学工程评论》，第 5 卷，第 60–73 页，2012 年。[8] A. Hyv¨arinen 和 E. Oja，“独立成分分析：算法与应用”，《Neural Networks》，第 13 卷，第 4–5 期，第 411–430 页，2000 年。[9] J.-F. Cardoso，“盲信号分离：统计原理”，《IEEE会议录》，第 86 卷，第 10 期，第 2009–2025 页，1998 年。[10] S.-i. Amari，“自然梯度在学习中高效发挥作用”，《神经计算》，第 10 卷，第 2 期，第 251–276 页，1998 年。[11] S.-i. Amari、A. Cichocki 和 H. H. Yang，“一种新的盲信号分离学习算法”，载于《神经信息处理系统进展》，第 8 卷。麻省理工学院出版社，1996 年，第 757–763 页。[12] S.-H. Hsu、T. Mullen、T.-P. Jung 和 G. Cauwenberghs，“利用在线递归独立成分分析进行实时自适应脑电信号源分离”，《IEEE神经系统与康复工程汇刊》，第 24 卷，第 3 期，第 309–320 页，2016 年。[13] C. J. Li 和 M. I. Jordan，“在线张量独立成分分析的随机逼近”，2021 年，arXiv 预印本 arXiv:2012.14415。[14] T. Kim、T. Eltoft 和 T.-W. Lee，“独立向量分析：将独立成分分析扩展至多变量成分”，载于《独立成分分析与信号分离国际会议》。施普林格，2006 年，第 165–172 页。[15] M. Anderson、G.-S. Fu、R. Phlypo 和 T. Adalı，“独立向量分析：识别条件与性能界限”，《IEEE信号处理汇刊》，第 62 卷，第 17 期，第 4399–4410 页，2014 年。[16] A. Taleb 和 C. Jutten，“后非线性混合中的源分离”，《IEEE信号处理汇刊》，第 47 卷，2820，1999 年，第 10 期，第 2807 页。[17] F. R. Bach 和 M. I. Jordan，“核独立成分分析”，《机器学习研究期刊》，第 3 卷，7 月号，第 1–48 页，2002 年。[18] A. Hyv¨arinen、I. Khemakhem 和 H. Morioka，“用于无监督深度学习中有原则解耦的非线性独立成分分析”，《Patterns》，第 4 卷，第 10 期，2023 年。[19] A. Hyv¨arinen 和 H. Morioka，“通过时间对比学习和非线性独立成分分析进行无监督特征提取”，载于《神经信息处理系统进展》，第 29 卷，2016 年，第 3765–3773 页。[20] I. Khemakhem、D. Kingma、R. Monti 和 A. Hyv¨arinen，“变分自编码器与非线性独立成分分析：一个统一框架”，载于《第二十三届人工智能与统计国际会议论文集》，《机器学习研究论文集》系列，第 108 卷，2020 年，第 2207–2217 页。[21] H. Jaeger，“分析和训练循环神经网络的‘回声状态’方法”，德国国家信息技术研究中心（GMD），技术报告 148，2001 年。[22] H. Jaeger 和 H. Haas，“利用非线性：预测混沌系统并降低无线通信能耗”，《Science》，第 304 卷，第 5667 期，第 78–80 页，2004 年。[23] M. Luko˘sevi˘cius，“应用回声状态网络实用指南”，载于《神经网络：技巧与诀窍》，第 2 版，G. Montavon、G. B. Orr 和 K.-R. M¨uller 编。施普林格，2012 年，第 659–686 页。[24] J. Dong、R. Ohana、M. Rafa¨el、C. Raffel、F. Krzakala、S. Gigan 和 L. Daudet，“储备池计算与循环核及结构化变换的结合”，载于《神经信息处理系统进展》，第 33 卷，2020 年，第 16 785–16 796 页。[25] P. Singh 和 B. Raman，“作为状态空间模型的回声状态网络：系统视角”，2025 年，arXiv 预印本 arXiv:2509.04422。[26] J. Choi 和 P. Kim，“使用无监督储备池计算进行信号-噪声分离”，2024，arXiv 预印本 arXiv:2404.04870。[27] I. B. Yildiz、H. Jaeger 和 S. J. Kiebel，“ 重新审视回声状态性质 ”，*Neural Networks*，第 35 卷，第 1–9 页，2012。[28] L. Grigoryeva 和 J.-P. Ortega，“回声状态网络具有通用性”，*Neural Networks*，第 108 卷，第 495–508 页，2018。[29] A. Rahimi 和 B. Recht，“用于大规模核机器的随机特征”，载于神经信息处理系统进展，第 20 卷，2007 年，第 1177–1184 页。[30] R. Vershynin，《高维概率：数据科学应用导论》。剑桥大学出版社，2018 年，第 47 卷。[31] J. Miettinen、K. Nordhausen、H. Oja、S. Taskinen 和 J. Virta，“平方对称FastICA估计器”，信号处理，第 131 卷，第 402–411 页，2017。[32] J. Le Roux、S. Wisdom、H. Erdogan 和 J. R. Hershey，“信号失真比——半生不熟还是恰到好处？”，载于*IEEE*国际声学、语音与信号处理会议（*ICASSP*）会刊，2019 年，第 626–630 页。[33] E. Vincent、R. Gribonval 和 C. F´evotte，“盲音频源分离中的性能测量”，*IEEE*音频、语音与语言处理汇刊，第 14 卷，第 4 期，第 1462–1469 页，2006。